Anonymisierungsverfahren

Die Erfindung betrifft ein Verfahren zur Anonymisierung sensibler Daten innerhalb eines Datenstroms.

In Datenbanken werden Informationen zur langfristigen Aufbewahrung gespeichert. Der Wert solcher Informationssammlungen wird als wesentliches Gut von Organisationen angesehen. Aufgrund der Sensitivität wird im allgemeinen der Zugriff auf Datenbanken beschränkt, d.h. daß der Zugriff nur für autorisierte Anwender gemäß deren Rechteprofil möglich ist. In einem Rechteprofil kann festgelegt werden, wer auf welche Daten mit welchen Modi (z.B. lesend, schreibend) zugreifen kann. Ein gängiges Beispiel ist, daß nicht jeder Mitarbeiter eines Unternehmens Personaldaten einsehen kann. Auch gemäß dem „Need to know"-Prinzip können Mitarbeiter ausschließlich die Informationen einsehen, die sie zur Ausübung ihrer dienstlichen Tätigkeiten benötigen. Alle weiteren Informationen sind gesperrt. Für die Vergabe der Zugriffsrechte ist ein Administrator zuständig, von dessen Zuverlässigkeit der Datenschutz im wesentlichen abhängt.

Zur Datensicherung werden häufig Anonymisierungsverfahren eingesetzt, die diejenigen Daten, auf die kein Zugriff erfolgen soll, anonymisieren. Solche Verfahren werden insbesondere verwendet, wenn Daten einer Datenbank in Form eines Datenstroms übermittelt werden sollen, wobei sichergestellt werden muß, daß auf dem Übermittlungsweg kein unberechtigter Zugriff auf die Daten erfolgt. Ein Anwendungsbeispiel hierfür ist die Versendung eines Datenstroms per E-Mail. Dabei haben Sender und Empfänger volle Zugriffsrechte auf alle in der Datenbank enthaltenen Daten. Die Daten werden vor Absendung verschlüsselt, so daß Angreifer innerhalb des Internets keinen Zugriff auf die Daten nehmen können. Der Empfänger entschlüsselt die Daten und kann vollständigen Zugriff darauf nehmen.

Bei den bekannten Verfahren zum Schutz von Datenbanken wird die Autorisierung und Rechteprüfung typischerweise am Datenbank-Front End realisiert. Dies trifft z.B. für DB2™ von IBM zu. Wird ein höheres Niveau bzgl. des Zugriffsschutzes gefordert, so gibt es kommerzielle Produkte, wie z.B. RACF™ (Ressource Access Control Facility) von IBM. Die Zugriffskontrolle wird jedoch auch hier von einem Administrator kontrolliert.

Eine klassische Situation, in der die herkömmlichen Verfahren unzureichend sind, ist eine Outsourcer/Insourcer-Beziehung. Ein Outsourcer läßt bestimmte Dienste durch

einen Insourcer erbringen und übergibt dem Insourcer alle dafür notwendigen Daten, die beim Insourcer in einer Datenbank gespeichert werden. Wenn der Outsourcer aus Datenschutzgründen oder aus Gründen des Kundenschutzes die Weitergabe von kundenidentifizierenden Daten eigenständig kontrollieren will, wird mit den bekannten Anonymisierungsverfahren entweder der Zugriff auf die gesamte Datenbank unterbunden oder die selektive Kontrolle über den Zugriff auf bestimmte Daten einem Administrator unterstellt, der im dem Hause des Insourcers angesiedelt ist. Grundsätzlich wäre der Zugriff somit auch auf sensible Daten möglich.

Es ist Aufgabe der vorliegenden Erfindung, ein Verfahren zur Verfügung zu stellen, das den Zugriff auf eine Datenbank ermöglicht, dabei aber bestimmte Daten innerhalb dieser Datenbank vom Zugriff ausschließt, ohne die Zuordnung der ausgeschlossenen Daten zu den restlichen Daten zu zerstören. Die Datenbank soll zur Bearbeitung der nicht geschützten Daten in dritte Hände gegeben werden können, ohne daß die Zugriffskontrolle auf die geschützten Daten aus der Hand gegeben wird.

Erfindungsgemäß wird ein Verfahren zur Anonymisierung sensibler Daten innerhalb eines Datenstroms mit folgenden Schritten vorgeschlagen:

a) Komprimierung des sensiblen Datenfeldes

b) Anonymisierung des sensiblen Datenfelds;

c) Kennzeichnung des anonymisierten sensiblen Datenfelds innerhalb des Datenstroms durch Start- und Stoppzeichen.

Erfindungsgemäß werden die sensiblen Daten innerhalb einer Datenbank selektiv anonymisiert. Die anonymisierten Datenfelder werden mit einem Start- und einem Stoppzeichen versehen, um sie für die spätere Deanonymisierung kenntlich zu machen.

Das erfindungsgemäße Verfahren kann insbesondere eingesetzt werden, wenn ein Datenbanknutzer Daten in einer Datenbank ablegt, und Teile der Daten durch einen Datenbankbetreiber bearbeitet werden sollen. Während der Datenbanknutzer autorisiert ist, sämtliche Daten zu lesen, sollen sensible Daten, wie z. B. kundenidentifizierende Informationen, für den Datenbankbetreiber anonymisiert und nicht deanonymisierbar sein. Die Anonymisierungsinformation verbleibt beim Datenbanknutzer. Die nicht anonymisierten Daten können vom Datenbankbetreiber ausgewertet und bearbeitet werden. Die Zuordnung der Daten zueinander bleibt erhalten.

Die sensiblen Daten können beispielsweise kundenidentifizierende Informationen sein, wobei die dem Kunden zugeordneten Daten zwecks statistischer Auswertung lesbar sein sollen. Die Datenbank kann mit dem erfindungsgemäßen Anonymisierungsverfahren partiell anonymisiert und an Dritte zur statistischen Auswertung und Bearbeitung weitergegeben werden. Die kundenidentifizierenden Daten sind für den Dritten nicht lesbar. Die Kontrolle darüber, welche Zugriffsrechte für welche Personen bestehen, verbleibt beim Datenbanknutzer. Die Zuordnung zwischen den bearbeiteten Daten und den jeweiligen anonymisierten Daten, wie Kundennamen, bleibt erhalten. Nach Rückgabe der ausgewerteten oder bearbeiteten Datenbank an den Datenbanknutzer kann dieser die Deanonymisierung vornehmen und die vollständige, bearbeitete Datenbank nutzen.

Das erfindungsgemäße Verfahren läßt sich insbesondere auch dann vorteilhaft anwenden, wenn die sensiblen Datenfelder eine vorgegebene Feldlänge aufweisen. Es versteht sich aber von selbst, daß das Verfahren ohne Einschränkung auch bei unbegrenzten Feldlängen entsprechend anwendbar ist. Auch wenn sich die nachfolgenden Ausführungen vermehrt auf sensible Datenfelder vorgegebener Feldlänge beziehen, ist dies nicht einschränkend zu verstehen.

Vorteilhaft kann vor der Anonymisierung des sensiblen Datenfeldes eine Komprimierung der Daten vorgenommen werden. Im Falle der vollständigen Füllung des Datenfeldes wird auf diesem Wege Platz für die Hinzufügung von Start- und Stoppzeichen zur Kennzeichnung des anonymisierten Datenfeldes geschaffen. Die Kennzeichnung ist notwendig zur späteren Deanonymisierung des Datenfeldes.

Ist das Datenfeld ohnehin nicht vollständig gefüllt, oder sind die Daten durch die Komprimierung soweit komprimiert, daß noch Platz im Datenfeld verbleibt, kann das Datenfeld vor der Anonymisierung durch Füllzeichen aufgefüllt werden.

Es stehen insbesondere zwei Möglichkeiten zur Anonymisierung des Datenfeldes zur Verfügung, nämlich die Pseudonymisierung und die Verschlüsselung.

Ist das Datenfeld vollständig gefüllt, wird vorzugsweise eine Pseudonymisierung vorgenommen. Dabei muß die Länge des verwendeten Pseudonyms so gewählt werden, daß im Datenfeld nach der Pseudonymisierung Platz für Start- und Stoppzeichen verbleibt.

Verbleibt innerhalb des Datenfeldes noch Platz, so wird das Datenfeld vorzugsweise durch Füllzeichen, insbesondere mit zufälligen Werten, zumindest teilweise aufgefüllt und anschließend verschlüsselt.

Die Auffüllung des Feldes mit zufälligen Werten sichert die Auflösung von Isonomien. Beispielsweise ist es erforderlich, daß häufig auftretende Namen, wie im deutschen Sprachraum Müller, Meier usw. verschieden verschlüsselt werden, damit über eine Analyse der Häufigkeit der Daten keine Rückschlüsse auf die Daten gezogen werden kann. Dies wird mit der Auffüllung des Datenfeldes durch zufällige Werte und anschließende Verschlüsselung erreicht.

In einer bevorzugten Ausführungsform des erfindungsgemäßen Verfahrens werden im verschlüsselten Datenfeld auch Informationen über den zur Verschlüsselung verwendeten Schlüssel abgelegt. Diese Schlüsselinformationen dienen dem Datenbanknutzer dazu, die verschlüsselten Daten entschlüsseln zu können. Auf diesem Wege können verschiedene Schlüssel zur Verschlüsselung der Daten verwendet werden, wobei jeweils innerhalb des Feldes die entsprechenden Schlüsselinformationen zur Identifizierung des Schlüssels abgelegt werden. Es versteht sich von selbst, daß der Füllgrad des Feldes so beschaffen oder durch Datenkompression erzeugt werden muß, daß Platz zum Ablegen einer Schlüsselinformation verbleibt.

Das Erkennen, welche Daten zu ver- bzw. entschlüsseln sind, kann durch eindeutige Kennzeichnung durch sogenannte Start- und Stoppzeichen, wie z.B. „{" und „}" realisiert werden. Diese Start- und Stoppzeichen dürfen im betroffenen System außer zur Kennzeichnung verschlüsselter Daten nicht verwendet werden. Dieser Ansatz hat den Vorteil, daß er unabhängig von den Anwendungen, die auf den Daten operieren, ist.

Gibt es im betrachteten System kein einziges eindeutiges Startzeichen, kann eine Menge von Startzeichen verwendet werden. Gleiches gilt für das Stoppzeichen. Im einfachsten Fall könnte die Menge der Startzeichen aus einem Zeichen bestehen, welches mit dem Stoppzeichen identisch ist. Dies hat allerdings wiederum den Nachteil, daß eine Synchronisierung in einem Fehlerfall alleine aufgrund der Kenntnis von Start- und Stoppzeichen nicht mehr möglich ist.

Das erfindungsgemäße Verfahren wird im folgenden anhand von verschiedenen Beispielen mit Bezug auf die beigefügten Abbildungen näher erläutert:

Fig. 1 zeigt die Kennzeichnung von sensiblen, zu anonymisierenden Daten;

Fig. 2 zeigt das Ablaufschema einer Ver- bzw. Entschlüsselung;

Fig. 3 zeigt den Ablauf eines Verschlüsselungsprozesses;

Fig. 4 zeigt die Struktur eines verschlüsselten Datenfeldes;

Fig. 5 zeigt den Ablauf eines Entschlüsselungsprozesses.

Das Anonymisierungsverfahren soll folgende Anforderungen erfüllen:

1. Häufig vorkommende Daten (z.B. die häufig auftretenden Namen Müller, Meier usw. im deutschen Sprachraum) sollen verschieden verschlüsselt werden. Dadurch soll verhindert werden, daß über die Analyse der Häufigkeit von Daten Schlüsse auf die Daten selbst gezogen werden können. Die Isonomien der Daten sollen aufgelöst werden.

2. Die Länge eines zu verschlüsselndes Datenfelds ist durch eine fixe, maximale Länge beschränkt, die im wesentlichen durch das Datenbank-Design vorgegeben ist. Feldtypen, z.B. numerisch oder alphanumerisch dürfen nicht verändert werden. Diese Anforderung ermöglicht eine nachträgliche Integration des Verfahrens, ohne daß ein Betreiber eines Datenbanksystems seine Anwendungen zur Verarbeitung der Daten verändern muß.

3. Jedes verschlüsselte Datenfeld enthält alle Informationen außer Schlüssel und systemweite Parameter zur Entschlüsselung. Ein autarkes Verarbeiten jedes Datenfeldes ist deshalb möglich.

Die vorgenannten drei Eigenschaften sollen von dem gewählten Anonymisierungsverfahren gleichzeitig erfüllt werden.

Zur Durchführung des Verfahrens wird das zu anonymisierende Datenfeld zunächst auf seinen Füllgrad hin überprüft. Es muß sichergestellt werden, daß nach der Verschlüsselung noch genügend Platz innerhalb der vorgegebenen festen Datenfeldlänge verbleibt, um ein Start- sowie ein Stoppzeichen und eine Information für den verwendeten Schlüssel abzulegen.

Ist der Füllgrad des Datenfeldes zu groß um eine Verschlüsselung mit den vorgenannten Kriterien durchführen zu können, wird das Datenfeld zunächst komprimiert. Führt auch die Komprimierung des Datenfeldes nicht zu einer hinreichend kleinen Feldgröße, erfolgt die Pseudonymisierung. Das Pseudonym muß so gewählt werden, daß die oben unter 2.) vorgegebene Bedingung hinsichtlich des Füllungsgrades des Datenfeldes erfüllt wird.

Ist der Füllgrad des Datenfeldes hinreichend gering, um eine Verschlüsselung des Datenfeldes zu ermöglichen, wird die Verschlüsselung vorgenommen. Dafür wird das

Datenfeld zunächst bis zum maximal möglichen Füllgrad mit zufälligen Werten aufgefüllt.

Bei geringem Informationsgehalt des Datenfelds kann vor der Auffüllung eine Datenkomprimierung vorgenommen werden, um Isonomien besser auflösen zu können.

Anschließend wird die Verschlüsselung vorgenommen. Der verwendete Verschlüsselungsalgorithmus kann beliebig gewählt werden. Gängige Algorithmen sind z.B. IDEA (International Data Encryption Algorithm) oder DES (Data Encryption Standard).

Das verschlüsselte Datenfeld wird dann mit einem Start- und einem Stoppzeichen gekennzeichnet. Außerdem wird im Datenfeld an einer vorher definierten Position eine Information über den zur Verschlüsselung verwendeten Schlüssel abgelegt.

Das nachfolgende Beispiel soll das Verfahren veranschaulichen:

Die Datenfeldlänge beträgt 40 Zeichen. Inhalt des unverschlüsselten Datenfeldes ist der Name „Meier". Als Startzeichen dient „{", als Stoppzeichen „}". Das Datenfeld wird auf die volle Feldlänge aufgefüllt und mit Start- und Stoppzeichen versehen, also:

{Meier.....}.

An das Verfahren werden die 40 Zeichen zwischen den Start- und Stoppzeichen übergeben. Die Verschlüsselung ergibt dann ein 40 Zeichen langes Datenfeld einschließlich Start- und Stoppzeichen, also z.B.:

{ch74nHhdjqa.....yjas8}.

In den verschlüsselten Datenfeldern sind k Bits zur Kennzeichnung des verwendeten Schlüssels aus einem Schlüsselsatz vorgesehen. Somit ist es möglich, 2^k verschiedene Schlüssel darzustellen. Durch die Aufnahme von Zusatzinformationen in die verschlüsselten Datenfelder, wie z.B. Menge von Start- und von Stoppzeichen, Schlüsselbits und Informationen über den verwendeten Initialisierungssektor für den Verschlüsselungsalgorithmus ist eine Komprimierung der zu verschlüsselnden Datenfelder notwendig.

In der beigefügten **Fig. 2** ist die Ver- bzw. Entschlüsselung von Datenfeldern dargestellt. Die einzelnen Schritte werden nachfolgend näher erläutert.

Die Beschreibung des Verfahrens geht von den folgenden Voraussetzungen aus:

- Jedes Zeichen wird durch ein Byte dargestellt (z.B. ASCII- oder EBCDIC-Code). Vor der Ver- bzw. Entschlüsselung werden alle Zeichen eines Feldes in einen internen Zeichensatz (ASCII) umgewandelt und danach wieder entsprechend konvertiert.

- Die unterschiedlichen Parameter sind wie folgt festgelegt:

  1. einen Zeichensatz (z.B. 91 bestimmte Zeichen des EBCDIC-Codes);

  2. eine Menge der Startzeichen und Stoppzeichen für verschlüsselte Datenfelder, die nicht im Zeichensatz enthalten sind;

  3. ein Ersatzzeichen für nicht zum Zeichensatz gehörende Zeichen (ist Bestandteil des Zeichensatzes);

  4. ggf. notwendige Füllzeichen (ist Bestandteil des Zeichensatzes);

  5. Verfahrensparameter für die Kompression;

  6. Angaben darüber, wie bei nicht erfolgreicher Komprimierung das ursprüngliche Datenfeld nachverarbeitet werden soll;

  7. Angaben zur Darstellung von Bitfolgen als Folgen zulässiger Zeichen;

  8. Angaben darüber, welcher der Schlüssel aus dem Schlüsselsatz verwendet werden soll.

In Abhängigkeit von der Mächtigkeit des Zeichensatzes lassen sich einzelne Bitsegmente jeweils zu Zeichenfolgen einer bestimmten Länge umformen (zum Beispiel können bei einem Zeichensatz von 91 Zeichen je 13 Bit in je 2 Zeichen effektiv umgeformt werden). Optimal wäre eine „gemeinsame" Umformung der gesamten Bitfolge durch Betrachtung der Folge als Binärzahl und Darstellung dieser Zahl zur Basis b = Mächtigkeit des Zeichensatzes.

Im folgenden wird ein Verfahren zur effektiven Codierung einer möglichst großen Bitfolge in ein Datenfeld einer vorgegebenen Länge beschrieben, das für eine Implementierung auf Systemen mit 32-Bit-Prozessoren vorgesehen ist. Zunächst wird für einen gegebenen Zeichensatz vom Umfang b vor der Grundinitialisierung einmalig folgendes berechnet („ln" bezeichnet hierbei den natürlichen Logarithmus):

- Bestimmung des Minimalwertes von x/y für ganzzahliges y von 1 bis 32 und ganzzahliges $x \geq y * \ln(2)/\ln(b)$.
  Beispiel: Bei $b = 91$ erhält man ein Minimum bei $x = 2$ und $y = 13$.

- Für alle Werte x' von 1 bis x-1 wird das jeweilige ganzzahlige Maximum $y'(x')$ mit $y'(x') * \ln(2)/\ln(b) \leq x'$ berechnet. Außerdem wird $y'(0) := 0$ gesetzt.
  Beispiel: Bei $b = 91$ und $x = 2$ erhält man $y'(1) = 6$.

Es läßt sich nun folgendermaßen eine Bitfolge in ein Datenfeld der Länge d umformen:

1. Umformung von je y Bit in je x Zeichen.
   Beispiel: Bei $b = 91$ werden je 13 Bit durch je 2 Zeichen dargestellt.

2. Falls die gegebene Datenfeldlänge d nicht durch x teilbar ist, dann werden $y'(x')$ Bit in die restlichen x' Zeichen umgeformt. Im Beispiel werden noch 6 Bit durch ein Zeichen dargestellt.

Sei s die Anzahl der verwendeten Startzeichen in den verschlüsselten Datenfeldern und

$$L(d,b,s) = L = ((d - s - 1) \text{ DIV } x)*y + y'((d - s - 1) \text{ MOD } x)$$

die Anzahl der Bits, die sich durch Anwendung des obigen Verfahrens in ein Datenfeld der Länge $(d - s - 1)$ umformen lassen. Der Wert $(d - s - 1)$ resultiert daraus, daß im verschlüsselten Datenfeld die Menge der Startzeichen der Länge s und das Stoppzeichen enthalten sein müssen.

Bei $d = 30$, $b = 91$ und $s = 1$ erhält man zum Beispiel $L = 14 * 13 + 0 = 182$, bei $d = 15$, $b = 91$ und $s = 3$ ergibt sich $L = 5 * 13 + y'(1) = 65 + 6 = 71$.

m = (L - k - Länge komprimierte Bitfolge) sei, die nach der Kompression noch zur Verfügung stehenden Bits, k Bits sind für die Nummer des verwendeten Schlüssels vorgesehen. Für die Kompression können die verschiedensten Methoden eingesetzt werden. In Abhängigkeit von dieser Zahl m wird festgelegt, wie der Initialisierungsvektor für die Verschlüsselung bereitgestellt und codiert wird.

Die geeignete Wahl des Initialisierungsvektors sorgt dafür, daß Isonomien aufgelöst werden. Es gibt hierfür prinzipiell die folgenden Möglichkeiten, die eingesetzt werden können:

- Verwendung von Zufallszahlen
- Verwendung von Zählern.

Zeitlich gestaffelt können verschiedene Schlüssel des aus k Schlüsseln bestehenden Schlüsselsatzes eingesetzt werden. Bei der Verschlüsselung ist festzulegen, welcher

dieser Schlüssel verwendet werden soll. Die Schlüsselnummer wird durch k Bits kodiert.

Wenn die aus k Bits für die Nummer des Schlüssels, den Bits für die Codierung des Initialisierungsvektors und den Bits des komprimierten Datenfeldes bestehende Bitfolge kürzer als erforderlich sein sollte, d.h. kleiner als *L* ist, so wird sie am Ende mit Bits „0" aufgefüllt, bis die maximal zulässige Bitlänge *L* erreicht ist.

Verschlüsselt wird der komprimierte Datenfeldinhalt.

Die Verschlüsselung kann mit einem Blockverschlüsselungsalgorithmus erfolgen und dem gespeicherten geheimen Schlüssel im CBC-Modus, wobei der letzte Block der Länge *j* (falls diese kürzer als 64 Bit ist) im CFB-Modus verschlüsselt wird (siehe z.B.ISO/IEC 10116, Informations Technologie - Modes of Operation for ann-bit Block Cipher Algorithm, 1991).

Bei der Betrachtung wird davon ausgegangen, daß die typische Blocklänge von 64 verwendet wird. Eine Verallgemeinerung auf andere Blocklängen ist offensichtlich. Eine andere Variante, die sog. Stromverschlüsselungsalgorithmen, könnten direkt zur zeichenweisen Verschlüsselung eingesetzt werden.

Zur Bildung des verschlüsselten Datenfeldes wird schließlich die erhaltene Zeichenfolge zwischen der Menge Startzeichen und dem Stoppzeichen eingefügt.

Sobald im Datenstrom die Startzeichenfolge erkannt wird, werden die nachfolgenden Zeichen in einen internen Speicher gegeben, bis das Stoppzeichen erscheint.

Falls sich unter den nachfolgenden Zeichen die Startzeichenfolge befindet, wird der Prozeß der Einspeicherung abgebrochen und bei der neuen Startzeichenfolge begonnen. Falls nach einer vorgegebenen Maximallänge noch kein Stoppzeichen festgestellt wurde, wird der Prozeß ebenfalls abgebrochen und es wird erneut nach der nächsten Startzeichenfolge gesucht. Falls zwischen der Menge Startzeichen und dem Stoppzeichen weniger als eine vordefinierte untere Schranke Zeichen sind, wird die Einspeicherung ebenfalls abgebrochen.

Nicht jedes Datenfeld kann so stark komprimiert werden, daß die angestrebte Anzahl Bits für den Initialisierungsvektor zur Verfügung steht. Je kürzer die Datensatzlänge ist, desto schlechter ist die Komprimierung, mit der Konsequenz, daß weniger Bits für den Initialisierungsvektor zur Verfügung stehen und somit weniger Möglichkeiten verschiedene Chiffrate für ein Datenfeld zu erzeugen.

In einem solchen Fall gibt es prinzipiell die folgenden drei Möglichkeiten fortzufahren:

1. Kürzung des Datenfeldes bis eine ausreichende Komprimierung erreicht werden kann. Dies ist aber zwangsläufig mit Informationsverlust verbunden.

2. Das betroffene Datenfeldes wird nicht verschlüsselt, es wird somit in Klartext bleiben. Dies kann möglicherweise akzeptabel sein, falls dies im Verhältnis zu der gesamten Menge zu verschlüsselten Datenfelder sehr selten vorkommt.

3. Verwendung des Pseudonymisierungsansatzes, dieser wird im folgenden beschrieben.

Bei vorgegebener fester Feldlänge, kann der Fall eintreten, daß keine ausreichende Komprimierung der Datensätze erreicht werden kann. Ist eine Kürzung oder das Weiterleiten in Klartext nicht akzeptabel, so kann die vollständige "Verschleierung" aller ausgewählten Datensätze, durch den Pseudonymisierungsansatz realisiert werden.

Analog zu einem Alias, erfolgt eine Verknüpfung von Datenfeldern und Pseudonymen und vice versa. Die Informationen werden in einer Tabelle gehalten.

Leutheusser-Schnarrenberger	<->	X1BXE.....H
Garmisch-Partenkirchen	<->	X2BXD9.....Z

Falls die Pseudonymisierung an mehreren räumlich getrennten Orten notwendig ist, müssen die an allen Standorten vergebenen Pseudonyme an allen anderen Standorten vorgehalten werden (Replikation). Dies bedeutet zusätzliche Kommunikationskosten. Es sind zusätzliche Maßnahmen zur Sicherung der Übertragung notwendig.

Die Speicherung von verschlüsselten Datenfeldern kann über längere Zeiträume, z.B. 5 – 15 Jahre, erfolgen. Die zeitlich gestaffelte Verwendung von mehr als einem Schlüssel ist aus den folgenden Gründen ratsam:

- Wird der Schlüssel bekannt, ist die gesamte Menge der verschlüsselten Datenfelder als offen gelegt zu betrachten.

- Die einem Krypto-Analysten zur Verfügung stehende Menge von verschlüsselten Datenfeldern, ist wesentlich geringer, wenn mehrere Schlüssel verwendet werden.

Deshalb sieht das Verfahren pro Menge von Datenbanknutzern, die kooperieren, k Schlüssel vor.

In einem Trust Center (vertrauenswürdige dritte Instanz), welches das notwendige technische und organisatorische Umfeld stellt, können die Schlüssel generiert werden.

Verschiedene Mengen von Datenbanknutzern, die nicht miteinander kooperieren, sollten verschiedene Mengen von Schlüsseln haben, die keinerlei Abhängigkeit von einander haben. So ist ausgeschlossen, daß eine Menge von Datenbanknutzern auf Datenbankinformationen der anderen Menge von Datenbanknutzern zugreifen kann.

Das Key Management besteht aus folgenden Funktionen:

1. Schlüsselerzeugung

   Erzeugung eines Schlüsselpaktets aus k Schlüsseln. Hierfür eignet sich besonders ein Hardware Zufallszahlengenerator. Im Nachgang der Schlüsselerzeugung können die generierten Schlüssel auf ein Schlüsselaufbewahrungsmedium, z.B. eine Chip- oder PCMCIA-Karte, gespeichert werden. Diese Medien können so konfiguriert werden, daß sie die kryptographischen Berechnungen selbst ausführen oder Schlüssel erst nach vorheriger Authentisierung herausgeben.

2. Schlüsselverteilung

   Vom Ort der Schlüsselgenerierung können die Schlüssel auf einem Schlüsselaufbewahrungsmedium zum Einsatzort (Endgerät) oder zur sicheren Aufbewahrung (Back-up) transportiert werden.

3. Schlüssel in Endgeräte einbringen

   Ein Endgerät zeichnet sich dadurch aus, daß es die notwendigen Ver- bzw. Entschlüsselungsprozesse ausführen kann. Ein solches Gerät kann eine speziell entwickelte Hardware oder ein PC sein. Die Schlüssel können aus dem Schlüsselaufbewahrungsmedium nach vorheriger Authentisierung in ein Endgerät geladen werden oder das Endgerät kann Aufträge zur Ver- und Entschlüsselung entgegennehmen. Der letzte Fall setzt eine entsprechende Ressource des Schlüsselaufbewahrungsmediums voraus, hat aber der Vorteil, daß die Schlüssel nie das Schlüsselaufbewahrungsmedium verlassen.

4. Schlüssel vernichten:

   Falls ein kooperierende Menge von Datenbanknutzern ein Schlüsselpaket aus k Schlüsseln nicht mehr benötigt, ist es möglich, die Schlüssel durch geeignete Maßnahmen zu vernichten, z.B. durch Vernichtung des Schlüsselauf-

bewahrungsmediums und Löschen des Schlüsselpakets aus den entsprechenden Endgeräten, falls vorhanden.

Patentansprüche

1. Verfahren zur Anonymisierung sensibler Daten innerhalb eines Datenstroms mit den folgenden Schritten:

   a) Komprimierung des sensiblen Datenfeldes
   b) Anonymisierung des sensiblen Datenfeldes.
   c) Kennzeichnung des anonymisierten sensiblen Datenfeldes innerhalb des Datenstroms durch Start- und Stoppzeichen.

2. Verfahren nach Anspruch 1, **dadurch gekennzeichnet,** daß das sensible Datenfeld vor der Anonymisierung durch Füllzeichen aufgefüllt wird.

3. Verfahren nach Anspruch 1 oder 2, **dadurch gekennzeichnet,** daß die zu anonymisierenden Daten pseudonymisiert werden.

4. Verfahren nach Anspruch 1 oder 2, **dadurch gekennzeichnet,** daß die zu anonymisierenden Daten verschlüsselt werden.

5. Verfahren nach Anspruch 4, **dadurch gekennzeichnet,** daß sensible Datenfelder vor der Verschlüsselung zumindest teilweise mit zufälligen Werten aufgefüllt werden.

6. Verfahren nach Anspruch 4 oder 5, **dadurch gekennzeichnet,** daß im verschlüsselten Datenfeld Informationen über den zur Verschlüsselung verwendeten Schlüssel abgelegt werden.

7. Verfahren nach einem der Ansprüche 1 bis 6, **dadurch gekennzeichnet,** daß das sensible Datenfeld eine feste Feldlänge aufweist.

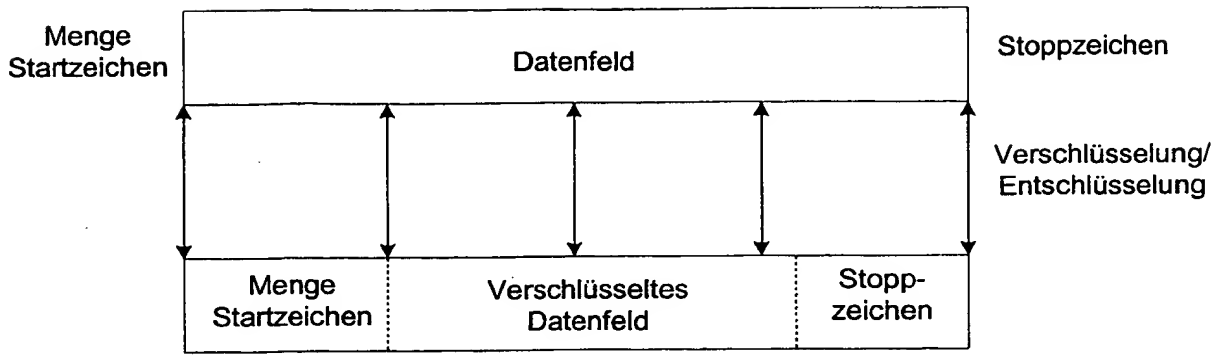
Menge
Startzeichen
Datenfeld
Stoppzeichen
Verschlüsselung/
Entschlüsselung
Menge
Startzeichen
Verschlüsseltes
Datenfeld
Stopp-
zeichen

Fig. 1

5

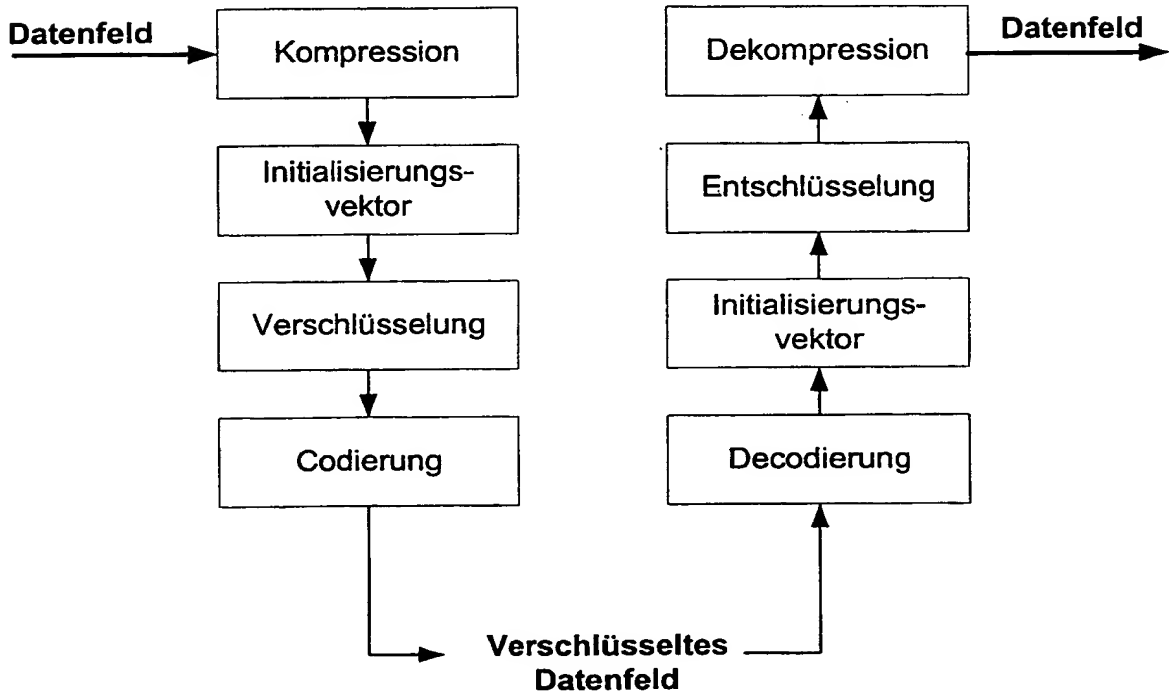
Datenfeld
Kompression
Initialisierungs-
vektor
Verschlüsselung
Codierung
Verschlüsseltes
Datenfeld
Decodierung
Initialisierungs-
vektor
Entschlüsselung
Dekompression
Datenfeld

Fig. 2

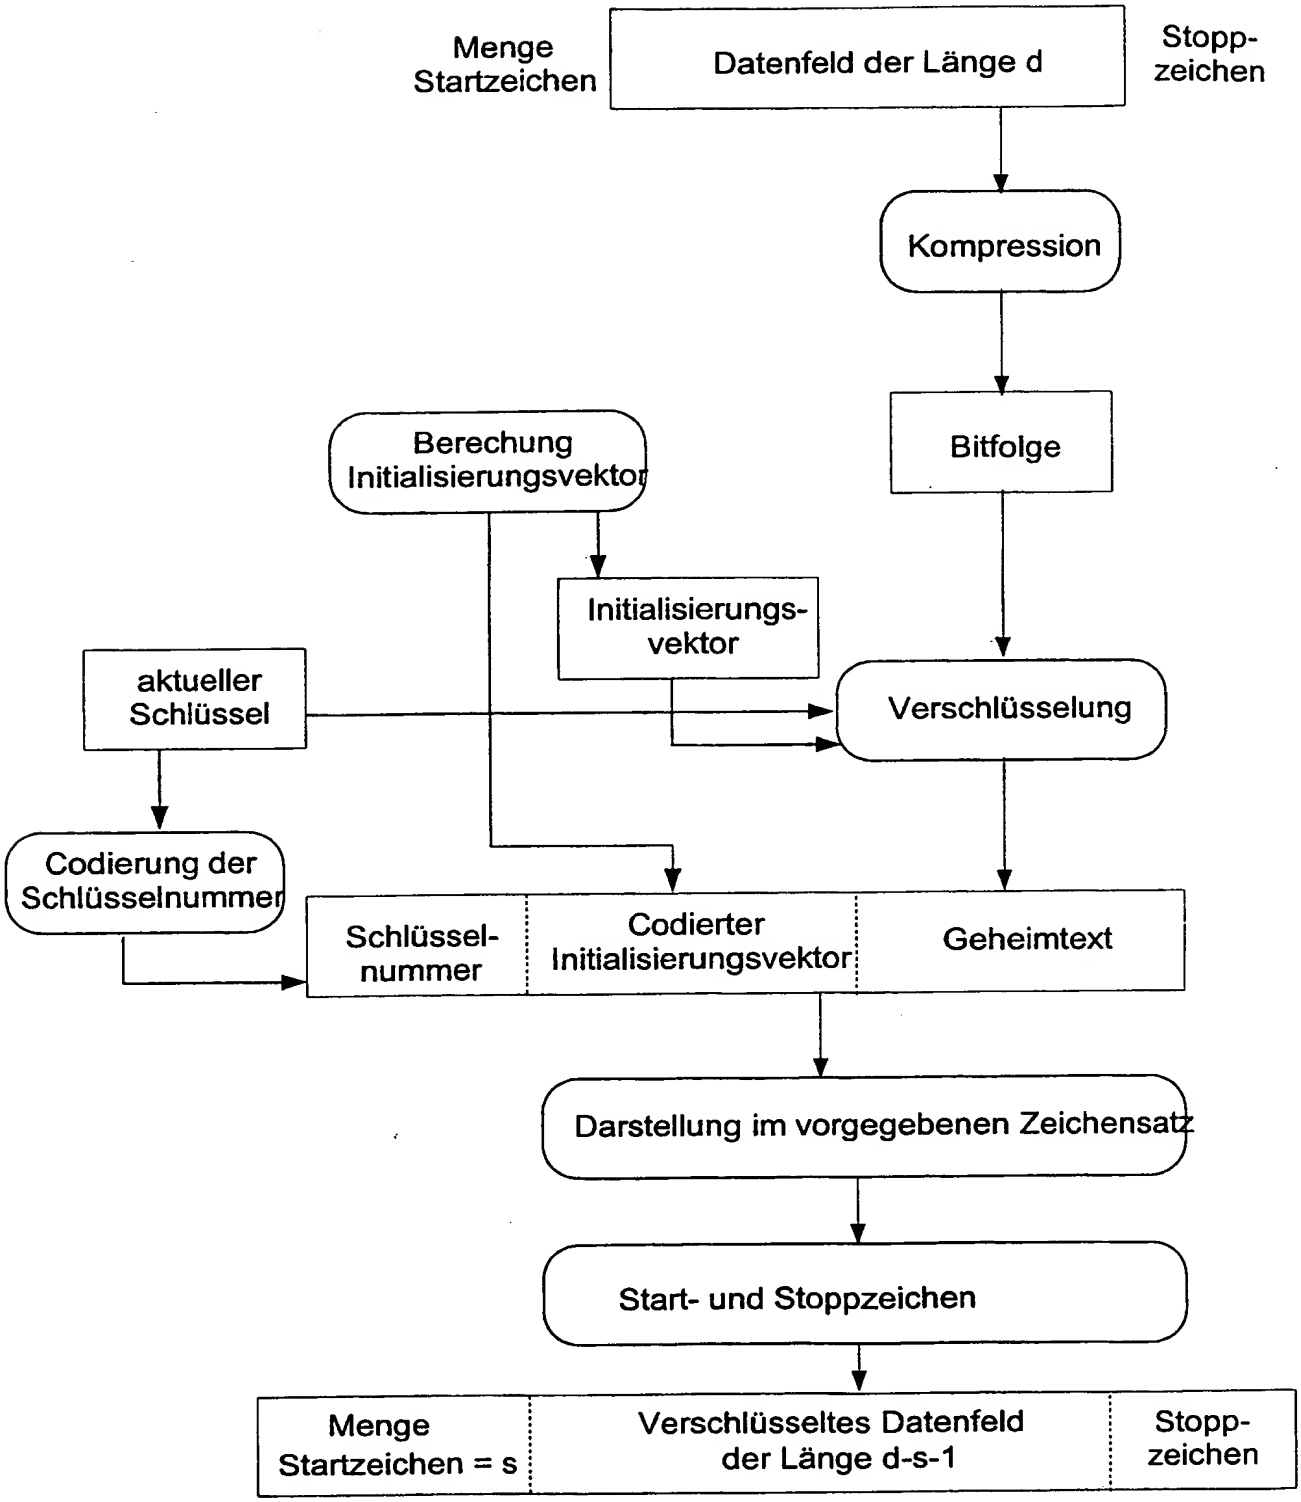
Menge Startzeichen
Datenfeld der Länge d
Stopp-zeichen
Kompression
Bitfolge
Berechung Initialisierungsvektor
Initialisierungs-vektor
aktueller Schlüssel
Verschlüsselung
Codierung der Schlüsselnummer
Schlüssel-nummer
Codierter Initialisierungsvektor
Geheimtext
Darstellung im vorgegebenen Zeichensatz
Start- und Stoppzeichen
Menge Startzeichen = s
Verschlüsseltes Datenfeld der Länge d-s-1
Stopp-zeichen

Fig. 3

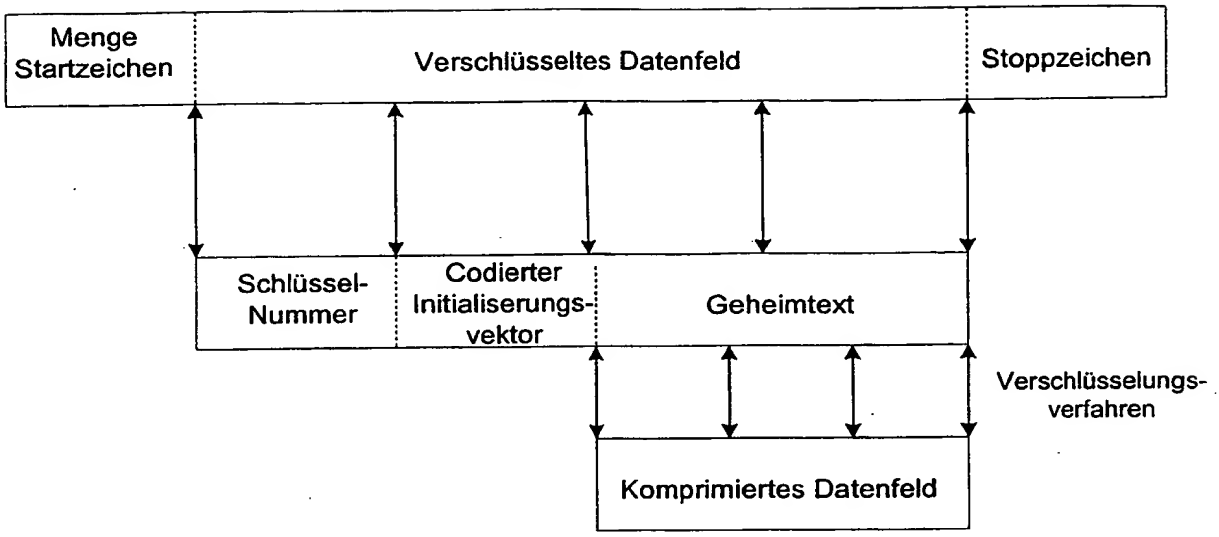
Menge Startzeichen
Verschlüsseltes Datenfeld
Stoppzeichen
Schlüssel-Nummer
Codierter Initialiserungs-vektor
Geheimtext
Verschlüsselungs-verfahren
Komprimiertes Datenfeld

Fig. 4

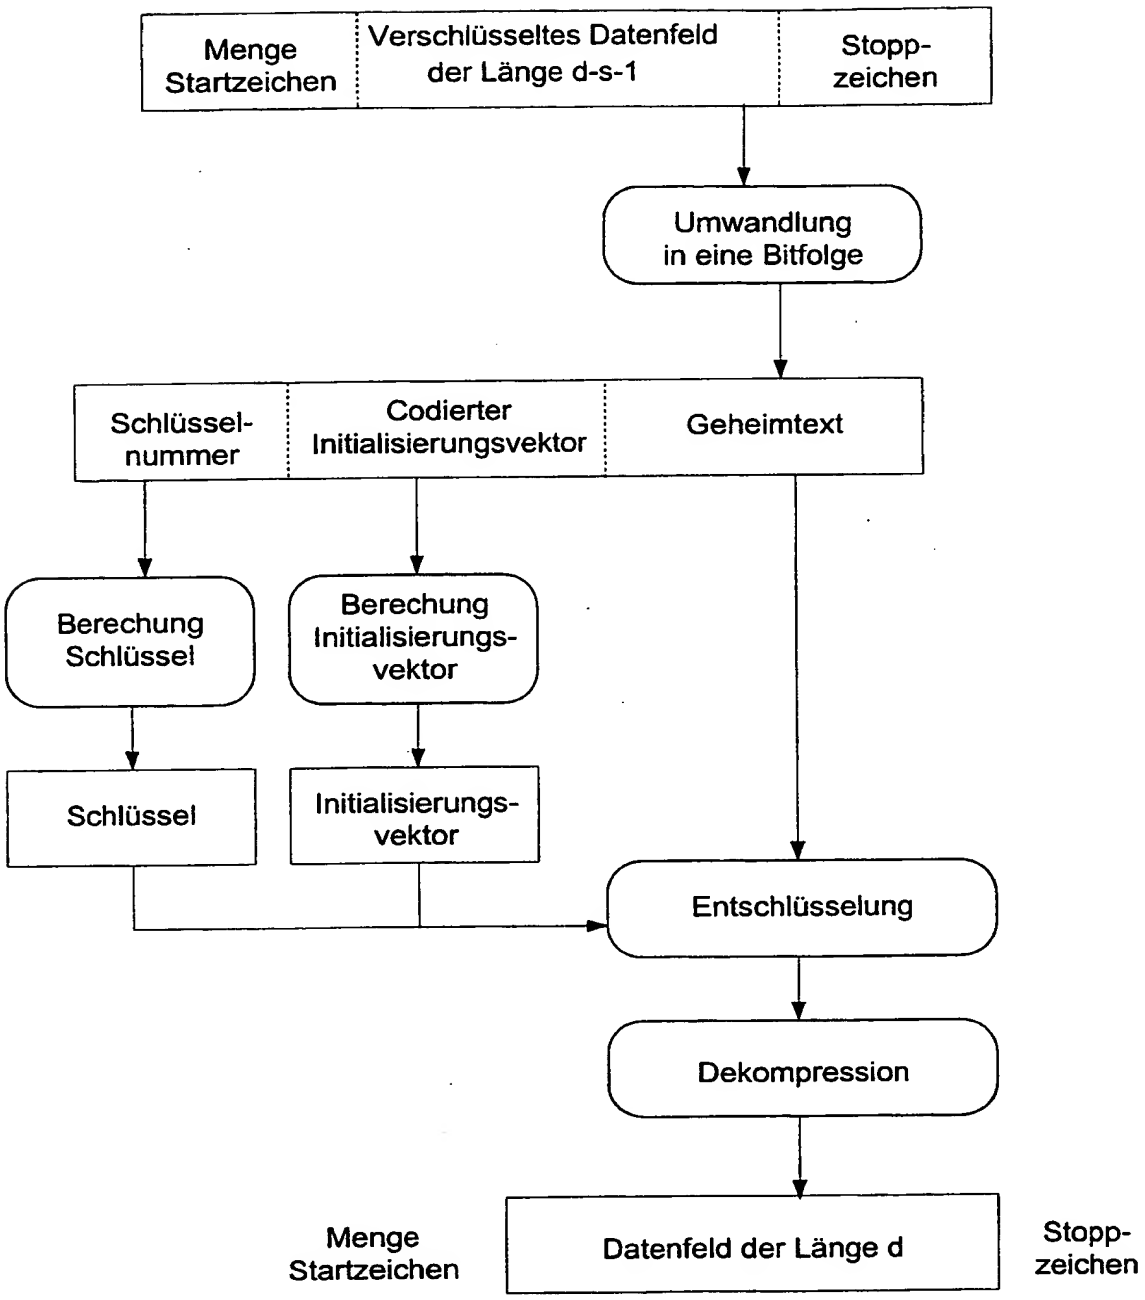
Menge Startzeichen
Verschlüsseltes Datenfeld der Länge d-s-1
Stopp-zeichen
Umwandlung in eine Bitfolge
Schlüssel-nummer
Codierter Initialisierungsvektor
Geheimtext
Berechung Schlüssel
Berechung Initialisierungs-vektor
Schlüssel
Initialisierungs-vektor
Entschlüsselung
Dekompression
Menge Startzeichen
Datenfeld der Länge d
Stopp-zeichen

Fig. 5

(12) NACH DEM VERTRAG ÜBER DIE INTERNATIONALE ZUSAMMENARBEIT AUF DEM GEBIET DES PATENTWESENS (PCT) VERÖFFENTLICHTE INTERNATIONALE ANMELDUNG

(19) Weltorganisation für geistiges Eigentum
Internationales Büro

(43) Internationales Veröffentlichungsdatum
21. September 2000 (21.09.2000)

PCT

(10) Internationale Veröffentlichungsnummer
WO 00/56005 A3

(51) Internationale Patentklassifikation[7]: H04L 29/06

(21) Internationales Aktenzeichen: PCT/DE00/00586

(22) Internationales Anmeldedatum:
2. März 2000 (02.03.2000)

(25) Einreichungssprache: Deutsch

(26) Veröffentlichungssprache: Deutsch

(30) Angaben zur Priorität:
199 11 176.6 12. März 1999 (12.03.1999) DE

(71) Anmelder *(für alle Bestimmungsstaaten mit Ausnahme von US)*: **LOK LOMBARDKASSE AG** [DE/DE]; Grüneburgweg 102, D-60323 Frankfurt am Main (DE).

(72) Erfinder; und

(75) Erfinder/Anmelder *(nur für US)*: **NEHL, Roland** [DE/DE]; Wiesenstrasse 33, D-35789 Weilmünster (DE).

(74) Anwalt: **MAHLER, Peter**; Feddersen Laule Ewerwahn Scherzberg Finkelnburg Clemm, Jungfernstieg 51, D-20354 Hamburg (DE).

(81) Bestimmungsstaaten *(national)*: CA, JP, US.

(84) Bestimmungsstaaten *(regional)*: europäisches Patent (AT, BE, CH, CY, DE, DK, ES, FI, FR, GB, GR, IE, IT, LU, MC, NL, PT, SE).

Veröffentlicht:
— *Mit internationalem Recherchenbericht.*

(88) Veröffentlichungsdatum des internationalen Recherchenberichts: 28. Dezember 2000

[Fortsetzung auf der nächsten Seite]

(54) Title: ANONYMIZATION METHOD

(54) Bezeichnung: ANONYMISIERUNGSVERFAHREN

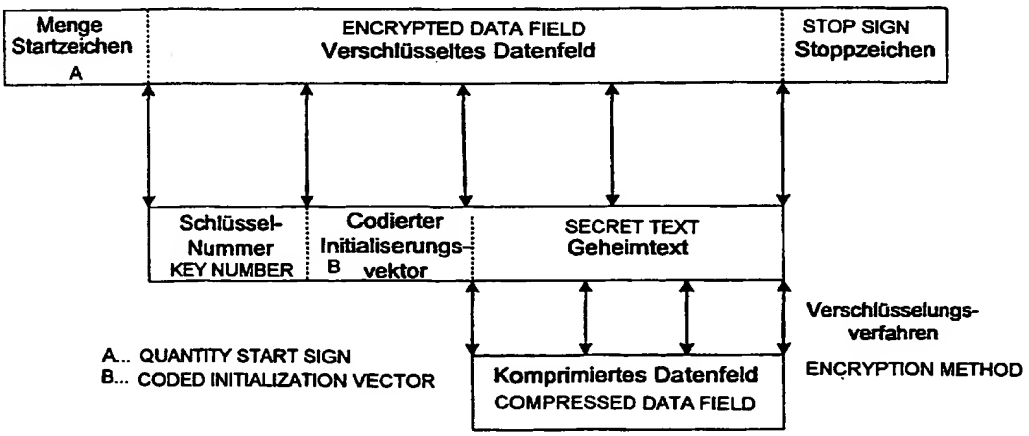

(57) Abstract: The invention relates to a method for rendering anonymous sensitive data within a data stream. The invention provides a method which comprises the following steps: Compressing the sensitive data field; rendering anonymous the sensitive data field, and distinguishing the anonymized sensitive data field within the data stream by means of start and stop signs.

(57) Zusammenfassung: Die Erfindung betrifft ein Verfahren zur Anonymisierung sensibler Daten innerhalb eines Datenstroms. Erfindungsgemäß wird ein Verfahren vorgeschlagen, das die Schritte Komprimierung des sensiblen Datenfeldes, Anonymisierung des sensiblen Datenfeldes und Kennzeichnung des anonymisierten sensiblen Datenfeldes innerhalb des Datenstroms durch Start- und Stopzeichen umfaßt.

WO 00/56005 A3

Zur Erklärung der Zweibuchstaben-Codes, und der anderen Abkürzungen wird auf die Erklärungen ("Guidance Notes on Codes and Abbreviations") am Anfang jeder regulären Ausgabe der PCT-Gazette verwiesen.

INTERNATIONAL SEARCH REPORT

International Application No
PCT/DE 00/00586

A. CLASSIFICATION OF SUBJECT MATTER
IPC 7 H04L29/06

According to International Patent Classification (IPC) or to both national classification and IPC -

B. FIELDS SEARCHED

Minimum documentation searched (classification system followed by classification symbols)
IPC 7 H04L H03M

Documentation searched other than minimum documentation to the extent that such documents are included in the fields searched

Electronic data base consulted during the international search (name of data base and, where practical, search terms used)
EPO-Internal, WPI Data, PAJ, INSPEC, IBM-TDB, COMPENDEX

C. DOCUMENTS CONSIDERED TO BE RELEVANT

Category *	Citation of document, with indication, where appropriate, of the relevant passages	Relevant to claim No.
A	US 5 768 391 A (ICHIKAWA BRYAN K) 16 June 1998 (1998-06-16) abstract column 1, line 47 -column 2, line 13 column 3, line 62 -column 4, line 13 column 4, line 62 -column 5, line 10	1-7
A	WO 95 26595 A (SCIENTIFIC ATLANTA) 5 October 1995 (1995-10-05) abstract page 4, line 6 -page 5, line 2 page 7, line 12 -page 9, line 7 page 10, line 31 -page 11, line 6 page 12, line 11 -page 13, line 18	1-7

-/--

[X] Further documents are listed in the continuation of box C.

[X] Patent family members are listed in annex.

* Special categories of cited documents :

"A" document defining the general state of the art which is not considered to be of particular relevance

"E" earlier document but published on or after the international filing date

"L" document which may throw doubts on priority claim(s) or which is cited to establish the publication date of another citation or other special reason (as specified)

"O" document referring to an oral disclosure, use, exhibition or other means

"P" document published prior to the international filing date but later than the priority date claimed

"T" later document published after the international filing date or priority date and not in conflict with the application but cited to understand the principle or theory underlying the invention

"X" document of particular relevance; the claimed invention cannot be considered novel or cannot be considered to involve an inventive step when the document is taken alone

"Y" document of particular relevance; the claimed invention cannot be considered to involve an inventive step when the document is combined with one or more other such documents, such combination being obvious to a person skilled in the art.

"&" document member of the same patent family

Date of the actual completion of the international search	Date of mailing of the international search report
4 September 2000	11/09/2000

Name and mailing address of the ISA	Authorized officer
European Patent Office, P.B. 5818 Patentlaan 2 NL - 2280 HV Rijswijk Tel. (+31-70) 340-2040, Tx. 31 651 epo nl, Fax: (+31-70) 340-3016	Lázaro Lõpez, M.L.

Form PCT/ISA/210 (second sheet) (July 1992)

C.(Continuation) DOCUMENTS CONSIDERED TO BE RELEVANT

Category °	Citation of document, with indication,where appropriate, of the relevant passages	Relevant to claim No.
A	WO 97 28652 A (TIERNAN COMMUNICATIONS INC) 7 August 1997 (1997-08-07) page 12, line 11 -page 13, line 12 page 21, line 1 -page 23, line 12 figures 4A,4B	1-7
A	US 5 668 810 A (CANNELLA JR JAMES E) 16 September 1997 (1997-09-16) column 8, line 58 -column 9, line 41 column 14, line 39-49 figure 3	1-7

INTERNATIONAL SEARCH REPORT

Information on patent family members

International Application No
PCT/DE 00/00586

Patent document cited in search report	Publication date	Patent family member(s)	Publication date
US 5768391 A	16-06-1998	AU 1565697 A	17-07-1997
		CA 2240893 A	03-07-1997
		EP 0870387 A	14-10-1998
		WO 9723983 A	03-07-1997
WO 9526595 A	05-10-1995	AU 7331894 A	17-10-1995
WO 9728652 A	07-08-1997	AU 2245097 A	22-08-1997
		CA 2241936 A	07-08-1997
		EP 0878098 A	18-11-1998
		JP 2000504181 T	04-04-2000
US 5668810 A	16-09-1997	CA 2174988 A	27-10-1996
		US 5854840 A	29-12-1998

INTERNATIONALER RECHERCHENBERICHT

Internationales Aktenzeichen
PCT/DE 00/00586

A. KLASSIFIZIERUNG DES ANMELDUNGSGEGENSTANDES
IPK 7 H04L29/06

Nach der Internationalen Patentklassifikation (IPK) oder nach der nationalen Klassifikation und der IPK

B. RECHERCHIERTE GEBIETE

Recherchierter Mindestprüfstoff (Klassifikationssystem und Klassifikationssymbole)
IPK 7 H04L H03M

Recherchierte aber nicht zum Mindestprüfstoff gehörende Veröffentlichungen, soweit diese unter die recherchierten Gebiete fallen

Während der internationalen Recherche konsultierte elektronische Datenbank (Name der Datenbank und evtl. verwendete Suchbegriffe)
EPO-Internal, WPI Data, PAJ, INSPEC, IBM-TDB, COMPENDEX

C. ALS WESENTLICH ANGESEHENE UNTERLAGEN

Kategorie°	Bezeichnung der Veröffentlichung, soweit erforderlich unter Angabe der in Betracht kommenden Teile	Betr. Anspruch Nr.
A	US 5 768 391 A (ICHIKAWA BRYAN K) 16. Juni 1998 (1998-06-16) Zusammenfassung Spalte 1, Zeile 47 -Spalte 2, Zeile 13 Spalte 3, Zeile 62 -Spalte 4, Zeile 13 Spalte 4, Zeile 62 -Spalte 5, Zeile 10	1-7
A	WO 95 26595 A (SCIENTIFIC ATLANTA) 5. Oktober 1995 (1995-10-05) Zusammenfassung Seite 4, Zeile 6 -Seite 5, Zeile 2 Seite 7, Zeile 12 -Seite 9, Zeile 7 Seite 10, Zeile 31 -Seite 11, Zeile 6 Seite 12, Zeile 11 -Seite 13, Zeile 18	1-7

-/—

[X] Weitere Veröffentlichungen sind der Fortsetzung von Feld C zu entnehmen

[X] Siehe Anhang Patentfamilie

° Besondere Kategorien von angegebenen Veröffentlichungen :
"A" Veröffentlichung, die den allgemeinen Stand der Technik definiert, aber nicht als besonders bedeutsam anzusehen ist
"E" älteres Dokument, das jedoch erst am oder nach dem internationalen Anmeldedatum veröffentlicht worden ist
"L" Veröffentlichung, die geeignet ist, einen Prioritätsanspruch zweifelhaft erscheinen zu lassen, oder durch die das Veröffentlichungsdatum einer anderen im Recherchenbericht genannten Veröffentlichung belegt werden soll oder die aus einem anderen besonderen Grund angegeben ist (wie ausgeführt)
"O" Veröffentlichung, die sich auf eine mündliche Offenbarung, eine Benutzung, eine Ausstellung oder andere Maßnahmen bezieht
"P" Veröffentlichung, die vor dem internationalen Anmeldedatum, aber nach dem beanspruchten Prioritätsdatum veröffentlicht worden ist
"T" Spätere Veröffentlichung, die nach dem internationalen Anmeldedatum oder dem Prioritätsdatum veröffentlicht worden ist und mit der Anmeldung nicht kollidiert, sondern nur zum Verständnis des der Erfindung zugrundeliegenden Prinzips oder der ihr zugrundeliegenden Theorie angegeben ist
"X" Veröffentlichung von besonderer Bedeutung; die beanspruchte Erfindung kann allein aufgrund dieser Veröffentlichung nicht als neu oder auf erfinderischer Tätigkeit beruhend betrachtet werden
"Y" Veröffentlichung von besonderer Bedeutung; die beanspruchte Erfindung kann nicht als auf erfinderischer Tätigkeit beruhend betrachtet werden, wenn die Veröffentlichung mit einer oder mehreren anderen Veröffentlichungen dieser Kategorie in Verbindung gebracht wird und diese Verbindung für einen Fachmann naheliegend ist
"&" Veröffentlichung, die Mitglied derselben Patentfamilie ist

Datum des Abschlusses der internationalen Recherche	Absendedatum des internationalen Recherchenberichts
4. September 2000	11/09/2000

Name und Postanschrift der Internationalen Recherchenbehörde	Bevollmächtigter Bediensteter
Europäisches Patentamt, P.B. 5818 Patentlaan 2 NL – 2280 HV Rijswijk Tel. (+31-70) 340-2040, Tx. 31 651 epo nl, Fax: (+31-70) 340-3016	Lázaro Lõpez, M.L.

1

C.(Fortsetzung) ALS WESENTLICH ANGESEHENE UNTERLAGEN

Kategorie°	Bezeichnung der Veröffentlichung, soweit erforderlich unter Angabe der in Betracht kommenden Teile	Betr. Anspruch Nr.
A	WO 97 28652 A (TIERNAN COMMUNICATIONS INC) 7. August 1997 (1997-08-07) Seite 12, Zeile 11 -Seite 13, Zeile 12 Seite 21, Zeile 1 -Seite 23, Zeile 12 Abbildungen 4A,4B	1-7
A	US 5 668 810 A (CANNELLA JR JAMES E) 16. September 1997 (1997-09-16) Spalte 8, Zeile 58 -Spalte 9, Zeile 41 Spalte 14, Zeile 39-49 Abbildung 3	1-7

1

INTERNATIONALER RECHERCHENBERICHT

Angaben zu Veröffentlichungen, die zur selben Patentfamilie gehören

Internationales Aktenzeichen
PCT/DE 00/00586

Im Recherchenbericht angeführtes Patentdokument	Datum der Veröffentlichung	Mitglied(er) der Patentfamilie	Datum der Veröffentlichung
US 5768391 A	16-06-1998	AU 1565697 A	17-07-1997
		CA 2240893 A	03-07-1997
		EP 0870387 A	14-10-1998
		WO 9723983 A	03-07-1997
WO 9526595 A	05-10-1995	AU 7331894 A	17-10-1995
WO 9728652 A	07-08-1997	AU 2245097 A	22-08-1997
		CA 2241936 A	07-08-1997
		EP 0878098 A	18-11-1998
		JP 2000504181 T	04-04-2000
US 5668810 A	16-09-1997	CA 2174988 A	27-10-1996
		US 5854840 A	29-12-1998